

Análise econométrica do *curtailment* na geração eólica no Brasil entre 2022 e 2024

Bruna Amaral Lanzillotti Barreto *

Felipe Cardoso Wilhelm da Costa †

Fernando Antonio Lucena Aiube ‡

Edison Americo Huarsaya Tito §

Daiane Rodrigues dos Santos ¶

25 de julho de 2025

Resumo

O mercado de geração eólica e solar brasileiro tem sido impactado por um significativo crescimento do *curtailment* ¹ da produção. Apesar de esse ser um fenômeno esperado no processo de integração das Energias Renováveis Variáveis (VRE) nos sistemas, fatores específicos do caso brasileiro como o perfil do crescimento da capacidade instalada, as dinâmicas da demanda e a gestão do sistema de transmissão parecem ter formado nos últimos anos a "tempestade perfeita" da restrição de geração. O presente trabalho realizou uma decomposição de séries temporais associadas ao fenômeno no período de janeiro de 2022 a dezembro de 2024 pelo método STL (*Seasonal and Trend decomposition using LOESS*), seguida de uma modelagem ARIMA com verificação dos efeitos das variáveis explicativas e elaboração de previsão de 12 semanas, considerando os princípios de modelagem Box-Jenkins. A sazonalidade foi identificada como elemento determinante do *curtailment* e o crescimento da Geração Distribuída (GD) como fator de maior impacto dentre as variáveis explicativas da parcela do fenômeno não atrelada ao seu caráter sazonal.

Palavras-chave: Restrição de Geração; Energia eólica, Energia Elétrica, Economia da Energia, *Curtailment*

Código JEL: C22, C53, N7.

*Mestranda do Programa de Pós-Graduação em Ciências Econômicas da Universidade do Estado do Rio de Janeiro (PPGCE-UERJ)

†Mestrando do Programa de Pós-Graduação em Ciências Econômicas da Universidade do Estado do Rio de Janeiro (PPGCE-UERJ)

‡Professor Associado da Faculdade de Ciências Econômicas - UERJ

§Professor Adjunto do Instituto de Matemática e Estatística - UERJ

¶Professora Adjunta da Faculdade de Ciências Econômicas - UERJ

¹Também conhecido como *constrained-off*, geração frustrada ou restrição de geração, o *curtailment* é definido pela Resolução Normativa Agência Nacional de Energia Elétrica (ANEEL) nº 1.030/2022 como "[...] a redução da produção de energia por usinas eólicas despachadas centralizadamente ou usinas/conjuntos de usinas eólicas considerados na programação, decorrente de comando do Operador Nacional do Sistema (ONS), que tenham sido originados externamente às instalações das respectivas usinas." [3]

1 Introdução

O crescimento das Energias Renováveis Variáveis ² vem sendo uma tendência global dos sistemas de energia nas últimas décadas, com conhecidas vantagens econômicas e ambientais. Essas formas de geração são responsáveis por mudanças na gestão dos sistemas de eletricidade, até então dominados por fontes mais controláveis, como a hidro e a termoeletrica, as quais se pode ajustar mais facilmente conforme a demanda.

O sistema de energia elétrica brasileiro, hoje considerado um sistema hidro-termo-eólico, é dominado majoritariamente pela geração hidroelétrica. Como forma de redução dessa dependência do regime hídrico e enfrentamento aos racionamentos e apagões vivenciados no final do século XX, sua expansão tem sido focada na diversidade tecnológica, com o crescimento de usinas eólicas, solares e hidroelétricas a fio d'água, além de alguns projetos de grandes usinas (Goldemberg, 2015; Mercedes, Rico e Pozzo, 2015) [15] [29].

No caso do Brasil, a partir de 2006, as tecnologias eólica e solar saltaram de 0,2% da capacidade de geração instalada no Sistema Integrado Nacional (SIN) para 21% em 2024. Um crescimento acelerado e concentrado na região Nordeste que oferece recursos de alta qualidade para a produção de energia através dessas tecnologias. A fonte eólica, que aparece pela primeira vez na Matriz Elétrica brasileira com 49 MW instalados alcançou 29.185 MW em 2024, menos de 20 anos depois: um crescimento médio de 32,7% ao ano, passando a representar 14% da matriz elétrica nacional (Operador Nacional do Sistema (ONS), 2025; Empresa de Pesquisa Energética (EPE), 2024) [32] [13].

Atualmente no Brasil um dos temas chaves do processo de integração dessas tecnologias no sistema é a gestão do excedente de oferta nos períodos que, pela disponibilidade climática de recursos, há uma alta de produção. O relatório *Integrating Solar and Wind: Global Experience and Emerging Challenges* da IEA (2024) [23] sobre o processo de integração das VRE nos sistemas nacionais aponta que, para maximizar o benefício dessas fontes, é necessária uma integração eficaz dessas tecnologias aos sistemas de energia, de modo a maximizar o volume de energia fornecido de maneira segura e com menor custo, que reduzam a dependência de combustíveis fósseis e evitando medidas de estabilização que sejam caras ou mesmo gerem prejuízo.

Em relação ao tema do excedente de oferta, por exemplo, o relatório indica a necessidade de uma maior flexibilidade dos sistemas e ferramentas como o uso de baterias, mecanismos de resposta à demanda³, uma gestão eficiente das tecnologias despacháveis e o próprio *curtailment* das VRE. Esse último, que é a limitação da produção de energia pelo operador do sistema, teve um crescimento expressivo no Brasil nos últimos anos e é o alvo da presente análise, uma vez que, adotado de forma crescente e quase como ferramenta exclusiva de gestão desse excedente, se comporta como um "cobertor curto", sendo origem de prejuízo para as empresas de geração eólica e solar e do crescimento do nível de incerteza nesse

²Acrônimo para a sigla em inglês *Variable Renewable Energy*, adotada pela Agência Internacional de Energia (IEA) para se referir as fontes de energia cuja produção é dependente da disponibilidade de recursos ambientais flutuantes, como energia gerada pela força dos ventos e correntezas marítimas ou de rios e irradiação solar.

³Por exemplo políticas de incentivo à redução do consumo de energia em horários de pico.

mercado.

Os principais marcos desse crescimento são bem conhecidos pelo setor. Foi observada uma desaceleração do crescimento da demanda de energia em relação às previsões nos últimos anos. Essa desaceleração está intimamente relacionada ao aumento exponencial da capacidade solar distribuída que tem recebido incentivos fiscais bastante expressivos. Por outro lado, em termos de infraestrutura do sistema, um evento de apagão em Agosto de 2023 teve como uma de suas consequências uma gestão mais conservadora da transmissão de energia entre os subsistemas, com a restrição da exportação da produção do Nordeste para as demais regiões do país.

Com o objetivo de investigar este fenômeno que tem estado no centro das discussões do setor de renováveis no Brasil, o presente trabalho conduziu uma análise de séries temporais associadas ao fenômeno do *curtailment* em usinas eólioeleétricas no período de janeiro de 2022 a dezembro de 2024. Foi feita uma decomposição pelo método STL, seguida de uma modelagem ARIMA com verificação dos efeitos das variáveis explicativas e elaboração de previsão de 12 semanas, considerando os princípios de modelagem Box-Jenkins.

Na seção 2 é apresentada uma breve revisão da literatura sobre o tema. Na seção 3 é detalhada a metodologia, além de apresentados os dados trabalhados. A seção 4 discute os resultados encontrados e a seção 5 conclui o estudo apontando para algumas possibilidades de avanço da análise do tema.

2 Revisão da Literatura

O tema das energias renováveis é alvo de uma vasta literatura, mas o fenômeno do *curtailment* especificamente tem um volume mais restrito e mais recente de produções acadêmicas, grande parte delas falando do fenômeno na China e nos Estados Unidos da América (EUA), que são dois países com parque de geração eólica maior e mais antigo. Muitos dos trabalhos são centrados nos aspectos de Engenharia, também em aspectos econômicos em escala micro ou ainda, como este trabalho, análises dos sistemas de forma geral. Nessa seção apresentamos brevemente algumas dessas abordagens.

López Prol e Zilberman (2023) [26] examinam as dinâmicas do *curtailment* no estado da Califórnia, nos EUA, entre 2014 e 2022. Suas análises usando métodos OLS, FGLS Prais-Winsten, regressão Beta e modelos aditivos generalizados mostram que o crescimento da geração solar, eólica e nuclear aumentam as taxas de restrição eólica e solar, por outro lado, como esperado, o aumento da demanda o reduz.

Acum et al (2023)[1], também analisando sistemas dos EUA, apontam que uma fração significativa (5-15%) da energia renovável gerada atualmente é desperdiçada nas redes elétricas ao redor do mundo devido a problemas de excesso de oferta e restrições de transmissão. Ser capaz de prever quando e onde o *curtailment* de energia renovável ocorre poderia melhorar a utilização dessas fontes renováveis. Os autores exploram estratégias de mitigação a partir de dados compilados de preços marginais nodais de sistemas elétricos dos EUA, com o objetivo de ajudar na descarbonização das redes elétricas, desbloqueando

o potencial da energia renovável.

Já Hurtado et al (2023)[20] por meio de análise direta de dados (*dispatch down reports*) e categorização de eventos, analisam o *curtailment* da energia eólica nos sistemas de energia irlandeses em 2020 e 2021. Os autores observaram, como se espera, uma correlação positiva entre a capacidade instalada de energia eólica e os níveis de *curtailment*. Junto a isso também demonstraram que o principal fator para o fenômeno no sistema energético foi a restrição operacional que exigiu cerca de 80% da operação das fontes convencionais e menos de 20% de fontes não síncronas como a eólica. Outras limitações sistêmicas, como a taxa de variação da frequência e a inércia, mostraram ter impacto insignificante no *curtailment* da energia eólica.

Alguns trabalhos interessantes se dedicaram a avaliar possibilidades de aproveitamento da energia que seria objeto de *curtailment* para outros usos que canalizem seu potencial econômico. Li et al (2023)[24], por exemplo aplicaram uma metodologia de aprendizado por *reinforcement learning* usada para tomar decisões otimizadas sob incerteza e simulações com dados realistas de geração eólica na Austrália. Os autores propõem desacoplar a operação conjunta do parque eólico e do sistema de armazenamento de energia por baterias que atuam como fontes de backup local, criando uma estratégia de oferta conjunta de energia que armazena o excedente de produção e realiza de arbitragem energética posterior.

Niaz, Liu e You (2022) [30] investigam a possibilidade de mitigação do *curtailment* utilizando a energia que seria restrita para alimentar a baixo custo uma fazenda de mineração de *bitcoin* no Texas, EUA, atividade que consome grandes volumes de energia. Segundo os autores, de forma melhor que baterias, por exemplo, uma fazenda de mineração de cripto moeda não apenas mitigaria a perda de energia, como a empregaria em uma atividade de alto potencial lucrativo, sendo uma opção mais vantajosa aos investidores do setor.

No Brasil, alguns trabalhos interessantes consideraram também o tema em escala micro e aplicaram modelos para auxiliar as empresas a lidarem com a restrição de sua produção e terem maior previsibilidade de seus resultados. No trabalho de Silva (2022) [34], por exemplo, é feita uma tentativa de predição do *curtailment* na unidade com algoritmo de *Random Forest* usando dados anemométricos coletados *in loco*. Já Silva (2023) [33] calcula a produtividade de empresas tendo o *curtailment* como parâmetro. Os trabalhos de Menezes (2022) [28] e de Lima (2021) [12] fazem análises da implementação de sistemas de baterias em usinas para gestão do *curtailment* e da variação diária do preço da energia.

3 Metodologia

Chatfield (1996)[10] cita alguns métodos de previsão de séries temporais. Entre os principais estão: extrapolação de Tendência (Harrison e Pearce, 1972[18], Meade, 1984[27]), Suavização Exponencial (Holt, 1958)[19], e Metodologia Box-Jenkins (Box e Jenkins, 1970)[8]. Mais recentemente Hyndman (2021)[21] considera outros métodos de previsão mais avançados e robustos que se baseiam nesses modelos.

Há ainda metodologias como o Modelo Profeta (*Prophet Model*) (SJ Taylor e Letham,

2018)[35], e o modelo de Vetores Autorregressivos, a partir de Hamilton (1994)[17] que insere uma relação bidirecional entre a variável dependente e as explicativas, diferente dos modelos citados até agora que impõem uma relação unidirecional. Ainda citam-se os Modelos de Redes Neurais e Previsões Bootstrapping (Bergmeir, C., Hyndman, RJ, e Benítez, JM, 2016)[6].

No presente artigo iremos aplicar a abordagem Box-Jenkins para realizar a previsão do *curtailment* na geração de energia eólica no Brasil. Antes disso, iremos decompor a série temporal para compreender melhor os padrões presentes nos dados e facilitar as análises e as respectivas previsões.

3.1 Decomposição de Séries Temporais

Conforme Hyndman (2021)[21] os dados de séries temporais podem exibir uma variedade de padrões, e geralmente é útil dividir uma série temporal em 3 componentes: tendência, sazonalidade e resíduos ou resto (*remainder*). A tendência ou tendência-ciclo captura mudanças de longo prazo ou movimentos de baixa frequência na série, a sazonalidade representa padrões que se repetem regularmente ao longo do tempo e o componente de resíduos representa os valores que não podem ser explicados pelas componentes sazonais e de tendência, incluindo a aleatoriedade.

A decomposição da série pode ser realizada de diferentes maneiras. As mais comuns são a aditiva, multiplicativa e a decomposição STL. A decomposição aditiva pode ser observada pela equação (1).

$$y_t = S_t + T_t + R_t \quad (1)$$

em que y_t é o dado observado; S_t é o componente sazonal; T_t é o componente de tendência-ciclo; e R_t é o componente de resíduo, todos no período t .

Já a decomposição multiplicativa pode ser representada pela equação (2).

$$y_t = S_t \times T_t \times R_t. \quad (2)$$

O autor ressalta que a decomposição aditiva é mais apropriada se a magnitude das flutuações sazonais, ou a variação em torno da tendência, não variar com o nível da série temporal. Quando a variação no padrão sazonal, ou a variação em torno da tendência-ciclo, parecer proporcional ao nível da série temporal, a decomposição multiplicativa é mais apropriada.

A Decomposição STL é um método versátil e robusto para decompor séries temporais. Ele lida com inúmeros padrões sazonais, o que é útil para as séries em análise neste trabalho, que foram semanais. Consegue também aliar a estimação de métodos não lineares com uma técnica de suavização não paramétrica⁴. O método também é mais vantajoso do que a decomposição clássica porque captura quando há variação do componente sazonal ao longo do tempo e essa taxa de mudança pode ser controlada de forma explícita a partir do conhecimento sobre as séries que estão sendo modeladas. Também é relevante a robustez

⁴Veja em Cleveland et al (1990)[11] e Bandara et al. (2022)[5]

frente a *outliers*, com as observações incomuns eventuais não afetando as estimativas de tendência e sazonalidade, apenas os resíduos.

3.2 Estratégia de Modelagem Box & Jenkins

A metodologia Box-Jenkins foi utilizada para mensurar o comportamento da série temporal, tendo sido realizadas as etapas de: identificação, estimação, diagnóstico e previsão. Conforme podemos observar na Figura 1 na primeira fase ocorre a identificação do processo aleatório que gerou os dados, em seguida a estimação dos parâmetros que o caracterizam, após isso ocorre o diagnóstico e a verificação se as hipóteses do modelo foram cumpridas. Caso negativo, uma nova fase de identificação deve ser considerada até que a verificação das hipóteses seja finalmente positiva, permitindo assim a última fase de previsão.

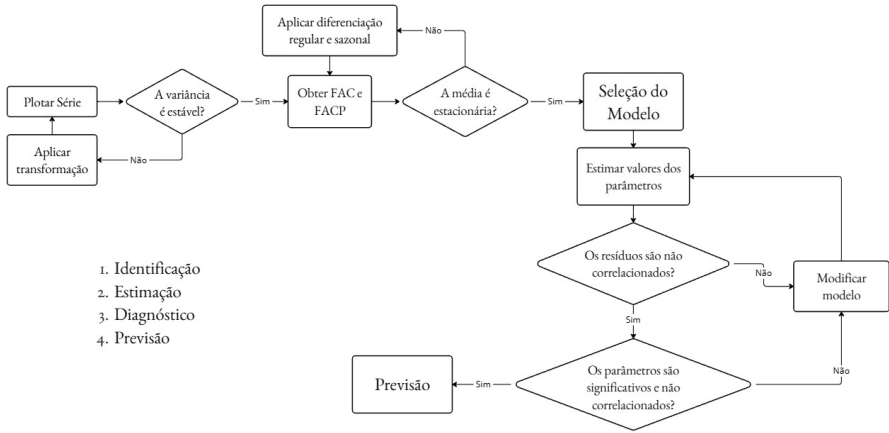


Figura 1: Abordagem de modelagem Box & Jenkins. Adaptado de Agarwal (2018) [2] pelos autores.

3.2.1 Identificação

De acordo com Gujarati e Porter (2011)[16] no estágio da identificação, a princípio, investiga-se os valores apropriados do ARIMA (p,d,q) a ser estimado. De modo que p é o número de termos autoregressivos (AR); d é o número de diferenças necessárias para tornar a série estacionária; q é o número de termos de média móvel (MA)⁵. O modelo ARIMA (p,d,q) é dado pela equação (3)

$$\left(1 - \sum_{i=1}^p \phi_i L^i\right) (1 - L)^d y_t = c + \left(1 + \sum_{j=1}^q \theta_j L^j\right) \varepsilon_t, \quad (3)$$

onde y_t é o valor da série temporal no instante t ; L representa o operador de defasagem ($L^k y_t = y_{t-k}$); ϕ_i os coeficientes autorregressivos; θ_j os coeficientes de média móvel; c a

⁵Uma análise inicial dos modelos AR(p), MA(q), ARMA(p,q), pode ser vista em Wooldridge (2013) [36]

constante do modelo e ε_t o termo de erro aleatório (ruído branco).

Vale ressaltar que se a série for sazonal, é necessário utilizar um modelo SARIMA, que é uma extensão do ARIMA para capturar padrões sazonais. Para isso, além dos parâmetros p , d e q , será necessário ajustar os parâmetros sazonais P , D e Q , juntamente com o período sazonal. O modelo SARIMA(p,d,q)(P,D,Q) s é dado pela equação (4):

$$\left(1 - \sum_{i=1}^P \Phi_i L^{i \cdot s}\right) (1-L^s)^D \left(1 - \sum_{i=1}^p \phi_i L^i\right) (1-L)^d y_t = c + \left(1 + \sum_{j=1}^Q \Theta_j L^{j \cdot s}\right) \left(1 + \sum_{j=1}^q \theta_j L^j\right) \varepsilon_t, \quad (4)$$

onde y_t é o valor da série temporal no tempo t ; L o operador de defasagem ($L^k y_t = y_{t-k}$); s o período sazonal (ex.: $s = 7$ para dados semanais); Φ_i os coeficientes autorregressivos sazonais; ϕ_i os coeficientes autorregressivos não sazonais; Θ_j os coeficientes de média móvel sazonais; θ_j os coeficientes de média móvel não sazonais; c a constante do modelo (se aplicável) e ε_t o termo de erro aleatório (ruído branco).

As principais ferramentas na etapa de identificação são a função de correlação amostral (ACF), a função de correlação amostral parcial (PACF) e os correlogramas resultantes, que são simplesmente as representações de ACF e PACF contra a extensão da defasagem. Assim, como tarefa inicial é preciso determinar p e q para a identificação de modelos que serão testados. Para isso, procede-se ao exame dos coeficientes de autocorrelação e dos coeficientes de autocorrelação parcial, que permitem medir a força relativa de interação entre as variáveis y_t defasadas.

Numa segunda parte desse processo é necessário efetuar testes de estacionariedade no modelo. Esse processo é de suma importância ao melhorar a capacidade de precisão e previsão dos modelos estatísticos. A estacionariedade de segunda ordem implica que as propriedades estatísticas da série, como média, variância e autocorrelação, permaneçam constantes ao longo do tempo. Isso permite que o modelo capture padrões e dependências temporais de forma mais eficaz. De acordo com Hyndman (2021)[21] uma série temporal estacionária é aquela cujas propriedades estatísticas não dependem do tempo em que a série é observada. Assim, a tendência e a sazonalidade afetarão o valor da série temporal em momentos diferentes. Por outro lado, uma série de ruído branco é estacionária — não importa quando você a observa, ela deve parecer a mesma em qualquer ponto do tempo.

Dessa forma, são realizados testes na série como o *Augmented Dickey-Fuller* (ADF) que ajuda a verificar se a mesma é estacionária ou não. A análise de seu p-valor abaixo de 0,05 ao rejeitar a hipótese nula, confirma a estacionariedade da série. Se ela não for estacionária, ou seja, suas propriedades estatísticas mudam ao longo do tempo, deve-se efetuar um processo de diferenciação na mesma para torná-la estacionária. Após a transformação é possível ajustar modelos como ARIMA ou SARIMA de forma mais eficaz, garantindo um modelo de previsão mais robusto.

3.2.2 Estimação

Após identificar as ordens adequadas para p , d e q (e P , D e Q , no caso de sazonalidade), o modelo ARIMA é ajustado aos dados, estimando os parâmetros do modelo. Nesse estágio é

necessário estimar os parâmetros dos termos autorregressivos e dos termos de média móvel incluídos no modelo. Esse cálculo pode ser feito de forma mais simples por mínimos quadrados, ou, se necessário, de maneira mais complexa a partir de métodos de estimação não linear dos parâmetros. Ao estimar o modelo ARIMA por máxima verossimilhança (MLE), a técnica encontra os valores dos parâmetros que maximizam a probabilidade de observar os dados fornecidos.

Para modelos ARIMA, os estimadores de MLE são idênticos aos de mínimos quadrados que seriam obtidos ao minimizar:

$$\sum_{t=1}^T \varepsilon_t^2. \quad (5)$$

Ainda seguindo Hyndman (2021)[21], vale ressaltar o critério de informação de Akaike (AIC), que é útil para determinar a ordem de um modelo ARIMA. Ele pode ser escrito como:

$$\text{AIC} = -2 \log(L) + 2(p + q + k + 1), \quad (6)$$

onde L é a verossimilhança dos dados, $k = 1$ se $c \neq 0$ e $k = 0$ se $c = 0$. Observe que o último termo entre parênteses é o número de parâmetros no modelo (incluindo σ^2 , a variância dos resíduos).

Para modelos ARIMA, o AIC corrigido (AICc) pode ser escrito como

$$\text{AICc} = \text{AIC} + \frac{2(p + q + k + 1)(p + q + k + 2)}{T - p - q - k - 2}, \quad (7)$$

e o Critério de Informação Bayesiano (BIC) pode ser escrito como:

$$\text{BIC} = \text{AIC} + [\log(T) - 2](p + q + k + 1). \quad (8)$$

Os modelos mais adequados são obtidos ao minimizar o AIC, AICc ou BIC. Entretanto, vale ressaltar que esses critérios de informação tendem a não ser bons guias para selecionar a ordem apropriada de diferenciação (d) de um modelo, mas apenas para selecionar os valores de p e q . Isso ocorre porque a diferenciação altera os dados nos quais a verossimilhança é computada, tornando os valores de AIC entre modelos com diferentes ordens de diferenciação não comparáveis.

3.2.3 Diagnóstico

Após escolhido um modelo ARIMA específico, e tendo estimado seus parâmetros, ocorre o processo de verificação do modelo selecionado e se o mesmo ajusta-se aos dados razoavelmente bem. Um teste simples do modelo selecionado é verificar se os resíduos estimados com base nesse modelo são ruídos brancos; se forem, pode-se aceitar o ajuste específico; do contrário, deve-se recomençar e voltar para a etapa de identificação.

Ou seja, ao ajustarmos um modelo ARIMA, estamos buscando capturar toda a estrutura de dependência serial presente na série. Logo, os resíduos do modelo não devem apresentar qualquer tipo de dependência no tempo. Num modelo ARIMA bem ajustado, os erros de previsão devem ser uma sequência de ruídos brancos, ou seja, não devem exibir

autocorrelações (e autocorrelações parciais) significativas.

Nessa etapa é necessário obter a partir dos resíduos do modelo estimado a função de autocorrelação e a função de autocorrelação parcial até uma certa defasagem. A partir de testes de autocorrelação como teste Ljung-Box⁶ é possível auferir se os resíduos estimados são puramente aleatórios, se forem não há mais necessidade de procurar outro modelo ARIMA, e pode-se seguir em frente.

Junto a isso, outros procedimentos para análise de resíduos são importantes, como a análise da normalidade e a presença de heterocedasticidade. De acordo com Chatfield (1996) [10], a normalidade dos resíduos é desejável para que as inferências estatísticas como intervalos de confiança e testes de hipóteses sejam válidos. Quanto à heterocedasticidade, a variabilidade não constante pode comprometer as estimativas do modelo. Assim, ao identificar heterocedasticidade, deve ser feita uma modificação ou escolha de um modelo adequado que trate esse comportamento, como o uso de modelos GARCH⁷ ou outras abordagens robustas.

3.2.4 Previsão

Por fim, chega-se à última etapa da metodologia que, depois de identificar, estimar e diagnosticar um modelo ARIMA(p,d,q), pode usá-lo para gerar previsões da série de forma pontual ou por intervalo. Na previsão pontual é necessário definir o previsor ótimo da série, de modo que a partir de um valor único, o modelo estima como o resultado mais provável para um período futuro da série temporal, condicional à informação disponível até o tempo t . Já a previsão por intervalo fornece um intervalo de confiança, que representa a incerteza associada à previsão, de modo que é necessário conhecer a distribuição do erro da previsão.⁸

3.3 Dados

Foram considerados na análise dados disponibilizados em portais de dados abertos do ONS (2024) [31] e da ANEEL (2024)[4]. Abaixo, além da descrição dos dados através de suas estatísticas principais na Tabela 1, cada uma das variáveis consideradas na elaboração dos modelos é apresentada. Todos os dados foram coletados em sua versão diária e posteriormente trabalhados como médias semanais para evitar a influência da sazonalidade ligada a mudança nos padrões de geração e consumo de energia nos dias úteis e fins de semana, que não é o objetivo deste estudo.

⁶Veja em On a Measure of a Lack of Fit in Time Series Models. Ljung, G. M., & Box, G. E. P. (1978) [25].

⁷Veja em Bollerslev (1986) [7]

⁸O detalhamento da parte algébrica pode ser visto em Hyndman (2021)[21]

Tabela 1: Principais estatísticas

Variáveis	<i>Curtailement</i> (MWh)	Capacidade (MW)	Demanda (MWmed)	Transmissão (MWmed)	GD (MW)
Média	44,4	24,7	73 791,5	79 732,0	46,3
Desv Pad	37,7	23,2	5 717,2	31 654,8	12,0
Mediana	25,5	19,6	73 720,2	80 759,7	45,1
Mínimo	7,8	0,0	63 450,8	-11 675,9	25,7
Máximo	171,4	135,1	86 190,2	149 206,5	80,0

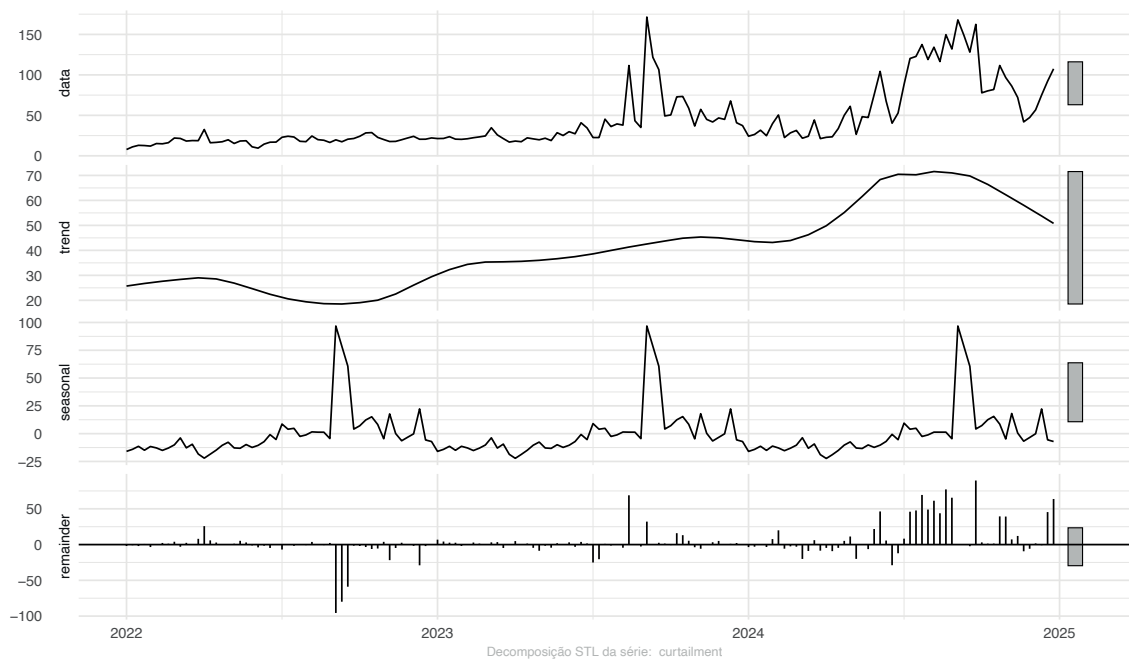
Nota: Os dados de Transmissão são referentes ao fluxo de energia da região Nordeste para as demais, por isso podem assumir valores negativos quando o volume de importação de energia para a região for maior que o de exportação.

3.3.1 *Curtailement*

O *curtailement* tem suas informações disponibilizadas na base de restrição de operação por *constrained-off* de usinas eólicas. Não foram incluídos dados do fenômeno na tecnologia solar em função do baixo volume de informações disponível. A unidade de medida é o MWh. Essa série foi a que definiu o recorte temporal da análise. Só há dados disponíveis a partir de outubro de 2021.

Na Figura 2 podemos observar a decomposição da série temporal. Na série original observamos uma clara mudança de padrão a partir de meados de 2023, quando o *curtailement* é expressivamente mais alto. A presença de uma sazonalidade anual também pode ser observada. Esse período de elevação sazonal do *curtailement* é justamente a "safra dos ventos", época do ano de maior disponibilidade de recurso para produção de energia eólica.

Figura 2: Decomposição STL da série *Curtailment* médio semanal - 2022-2024 (MWh)



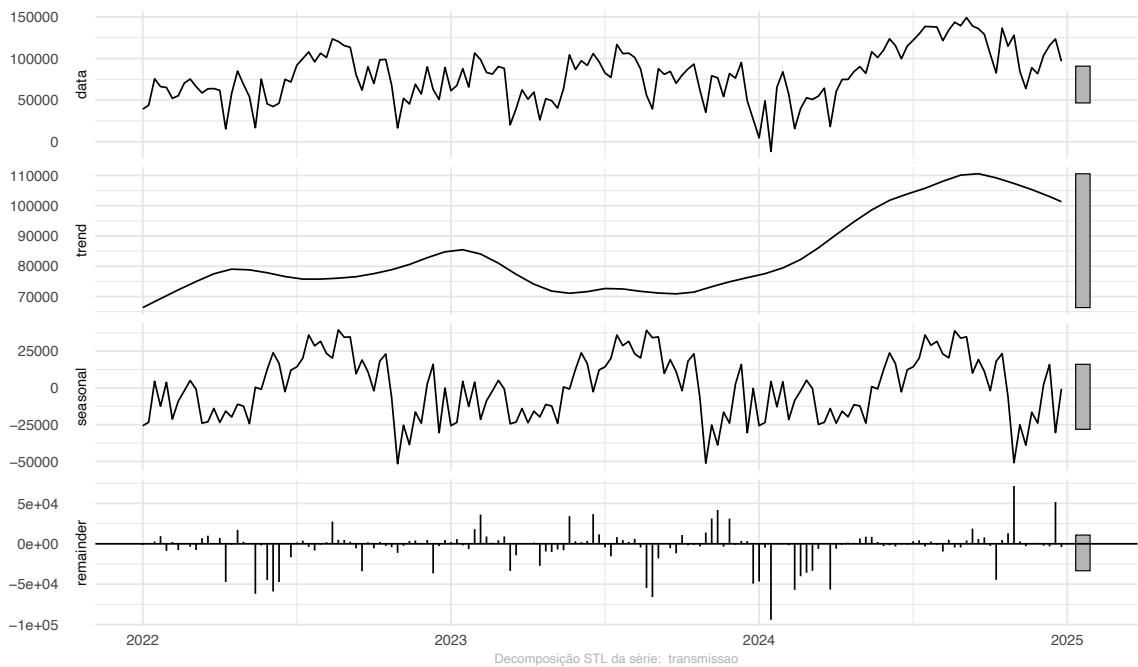
Fonte: Os autores

3.3.2 Transmissão de Energia

A transmissão de energia foi representada pelo intercâmbio de energia entre subsistemas, cujas grandezas são a soma das medidas de fluxo de potência ativa nas linhas de transmissão de fronteira entre os subsistemas. Foram selecionados apenas os valores dos fluxos de energia do subsistema Nordeste para as demais regiões. A unidade de medida é o MW médio.

Na decomposição da série na Figura 3 é interessante observar que a tendência capta bem o movimento realizado pelo ONS após o evento de apagão de agosto de 2021, quando a exportação de energia foi reduzida em cerca de 20% em prol de uma gestão mais conservadora das linhas. Alguns meses depois essa limitação seguiu presente mas em percentual menor, o que também aparece bem representado na série.

Figura 3: Decomposição STL da série Transmissão de Energia do subsistema Nordeste média semanal - 2022-2024 (MWmed)

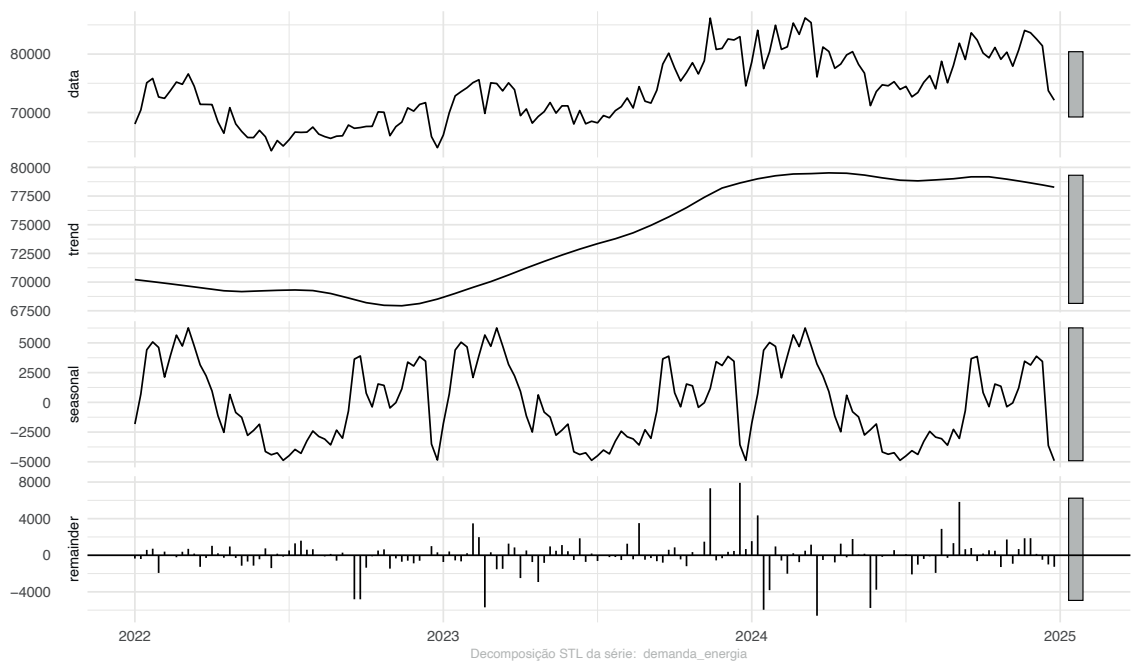


Fonte: Os autores

3.3.3 Demanda

A demanda de energia foi representada pela carga de energia diária, considerada em sua totalidade - para todo país. A unidade de medida também é o MW médio. Na decomposição da série na Figura 4 também observa-se a presença de uma sazonalidade anual e uma tendência de crescimento.

Figura 4: Decomposição STL da série Demanda de Energia nacional média semanal - 2022-2024 (MWmed)



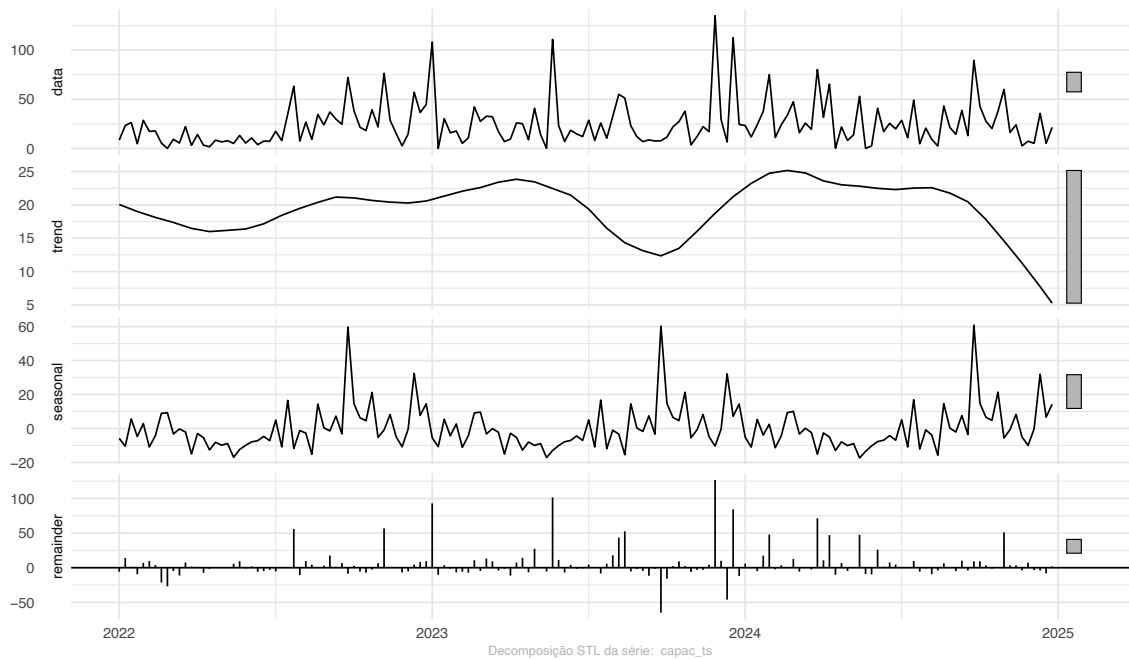
Fonte: O autores

3.3.4 Capacidade Instalada Centralizada

A capacidade instalada centralizada foi representada pela potência nominal de usinas despachadas pelo ONS. É a maior parte da capacidade instalada no país, incluindo usinas das tecnologias eólicoelétrica, fotovoltaica, hidroelétrica, nuclear e térmica. Os dados foram considerados como adição de nova capacidade em MW.

Na Figura 5 observamos uma queda da tendência no último ano, que pode estar associada a desaceleração dos investimentos em nova capacidade instalada eólicas e solar de projetos em escala industrial [22].

Figura 5: Decomposição STL da série Capacidade de Geração Centralizada adicionada média semanal - 2022-2024 (MW)

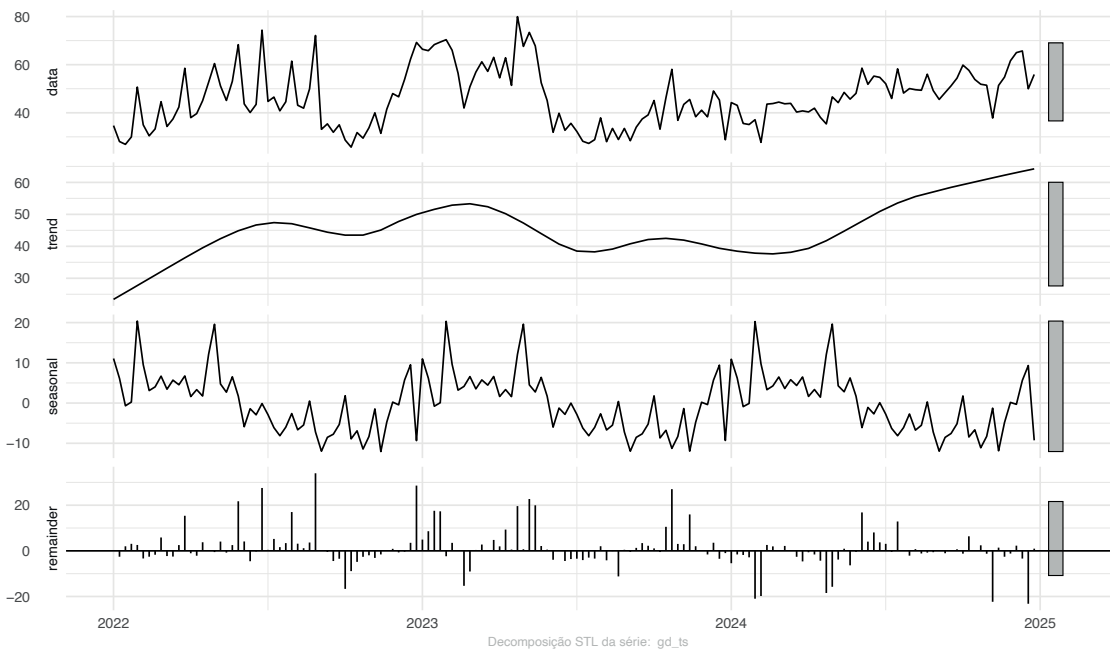


Fonte: Os autores

3.3.5 Geração Distribuída

A capacidade instalada em GD foi extraída da base de empreendimentos geração distribuída fotovoltaica. A GD é um modelo de produção de energia no qual ela é gerada no local ou próximo de onde será consumida. Abrange desde de consumidores residenciais até empresas e indústrias. Os dados foram considerados como adição de nova capacidade e estão expressos em MW. Na Figura 6 é possível ver a tendência de crescimento nos últimos anos e que não há uma sazonalidade muito definida.

Figura 6: Decomposição STL da série Capacidade de Geração Distribuída solar adicionada média semanal - 2022-2024 (MW)



Fonte: Os autores

4 Resultados

A aplicação da metodologia foi iniciada pela decomposição de todas as séries temporais e retirada do elemento de sazonalidade. A série sem sazonalidade foi tornada estacionária com a aplicação de uma diferenciação. O modelo identificado foi um ARIMA de ordem (1,0,3), conforme apresentado na Tabela 2. Os resíduos do modelo foram analisados⁹ e ele foi considerado robusto e apto a realização de previsões.

⁹Veja no Apêndice a análise completa dos resíduos 5

Tabela 2: Informações do Modelo de Regressão ARIMA (1,0,3)

Variável	Estimativa	Erro padrão	Valor z	Pr(> z)	Signif.
AR1	0.982	0.016	59.848	<2.2e-16	***
MA1	-0.333	0.083	-4.020	0.0	***
MA2	-0.158	0.084	-1.887	0.059	.
MA3	-0.183	0.094	-1.953	0.051	.
Intercepto	147.840	56.693	2.608	0.009	**
Capac.Inst.	0.043	0.055	0.793	0.428	
GD	0.375	0.162	2.308	0.021	*
Demanda	-0.0018	0.001	-2.507	0.012	*
Transmissão	0.0002	0.0	2.214	0.027	*
σ^2	350.10				
Log likelihood	-674.510				
AIC	1369.20				
BIC	1399.510				

Notas. Códigos de significância: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 '.' 1.

O parâmetro AR1, termo de autorregressão foi bastante significativo. Seu valor próximo de 1 sugeriu inércia no processo. É positivo, sugerindo que choques passados tendem a persistir e se somar positivamente à série. Dos parâmetros de média móvel, até o MA3 possui significância estatística a 10%, sendo esse escolhido para compor o ARIMA. O intercepto é positivo e significativo, indicando a existência de um termo constante e relevante.

Os coeficientes encontrados para as variáveis explicativas são coerentes com as dinâmicas já esperadas para os dados. A demanda é inversamente proporcional ao *curtailment*, uma vez que havendo maior demanda não há, ou há menos excedente de oferta. A capacidade centralizada adicionada não apresentou significância estatística.

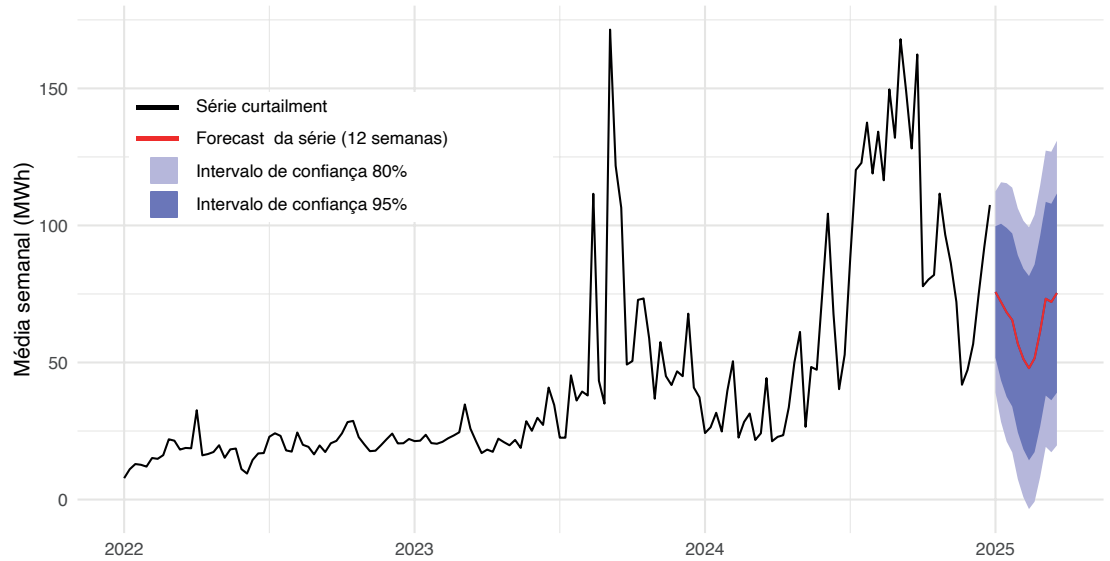
A geração solar distribuída, também conforme esperado, tem um impacto positivo e maior dentre as quatro. Com um crescimento exponencial nos últimos anos, tem sido a fonte de geração que mais cresce no Brasil e é hoje uma das mais representativas na matriz energética do país (EPE, 2024) [14]. Isso significa uma redução rápida da demanda - ou aumento da oferta, dependendo do ponto de vista. É, ao que parece pelo modelo e análise do contexto do setor, a provável maior responsável pela grande aceleração do crescimento do *curtailment*.

Já a transmissão apresenta um comportamento que à primeira vista causaria estranhamento, já que está positivamente relacionada ao *curtailment*. Entretanto, além de a relação ter um valor muito baixo, entendemos que, em função do recorte temporal da análise, há uma aparência de crescimento que pode ter influência nesse resultado. Como após o apagão há uma redução na capacidade de escoamento da produção do Nordeste, seguida de uma flexibilização dessa restrição, a janela analisada aparenta um crescimento.

Na Figura 7 é apresentada uma previsão do *curtailment* para as 12 primeiras semanas

de janeiro. Ela foi elaborada a partir do modelo com a sazonalidade reintegrada a série. Em uma análise dos dados reais preliminares do *curtailment* de janeiro de 2025, com três semanas completas e uma parcial, a previsão realizada mostrou-se coerente, com os dados reais dentro de suas margens, confirmando uma tendência de continuidade dos patamares altos de restrição.

Figura 7: *Forecast Curtailment* - 12 semanas, média semanal (MWh)



Fonte: Os autores

5 Conclusão

O trabalho apresentado nesse artigo realizou uma investigação sobre o *curtailment* na geração eólica no Brasil entre 2022 e 2024. Foi feita uma análise de séries temporais associadas ao fenômeno incluindo a decomposição pelo método STL e modelagem de um ARIMA (1, 0, 3) para análise de variáveis explicativas e elaboração de uma previsão.

A decomposição dos dados mostrou de forma interessante como a dinâmica dessas variáveis têm-se comportado para além da sazonalidade, reforçando as tendências gerais percebidas sobre o tema. O impacto mais significativo no *curtailment*, para além da sazonalidade, é o crescimento da geração solar distribuída. A proporção da influência da demanda indica que mesmo diante de um aumento dela, para compensar os efeitos da Geração Distribuída, o mesmo teria que ser bastante expressivo.

Se consideramos o processo de integração das VRE nos sistemas de energia sob a ótica da IEA, podemos afirmar que o cenário atual é de subaproveitamento da capacidade de geração através das VRE, o que tende a significar o desperdício de benefícios econômicos e ambientais proporcionados por essas tecnologias. No caso do sistema brasileiro, que é

predominantemente hídrico, essa afirmação pode parecer estranha à primeira vista, mas a necessidade de acionamento de térmicas em momentos de pico de demanda convivendo com o cenário de *curtailment* é um forte indicativo de que o uso de tecnologias como as baterias ou mesmo mecanismos de resposta à demanda, poderiam maximizar os resultados do setor de forma geral.

O setor hoje está envolto em uma série de discussões regulatórias ligadas ao tema. A provável entrada de baterias no sistema parece encomendada com as consultas públicas sobre o tema e a previsão de um leilão de capacidade para baterias ainda em 2025. Além disso, o futuro dos incentivos da geração distribuída são elementos importantes e em discussão. Do mesmo modo, novos usos da eletricidade como *data centers* com alto consumo e a eletrificação de usos finais na mobilidade urbana podem influenciar fortemente o fenômeno.

Com todos esses elementos, não há dúvidas de que as discussões acerca da gestão do *curtailment* seguirão por bastante tempo em pauta e a construção de bons modelos de *forecast* serão úteis. Investigações futuras podem lançar mão de dados climáticos na construção da previsão, uma vez que a disponibilidade de recurso eólico está cada vez mais sujeita a incertezas em função de mudanças nos padrões climáticos, como foi o longo *El Niño* de 2024.

Metodologicamente é possível avançar com modelos mais sofisticados, baseados em redes neurais, como *Long Short-Term Memory (LSTM)*, *Gated Recurrent Unit (GRU)* e o *Convolutional Neural Network (CNN)*¹⁰, por exemplo. São metodologias capazes de captar e modelar não linearidades na série de dados e realizar previsões mais complexas, sendo alternativas apropriadas para análises futuras sobre o tema.

Referências

- [1] ACUN, B., MORGAN, B., WU, C.-J., RICHARDSON, H., AND STEINSULTZ, N. Unlocking the potential of renewable energy through curtailment prediction. *Meta, WattTime* (2023). Meta (1), WattTime (2).
- [2] AGARWAL, V. Box-jenkins method of forecasting, May 2018. Apresentação no SlideShare, publicada em 30 de maio de 2018.
- [3] ANEEL. Resolução normativa aneel n^o 1.030, de 26 de julho de 2022, 2022. Accessed on 26 Jan. 2025.
- [4] ANEEL. Portal de dados abertos aneel. relação de empreendimentos de mini e micro geração distribuída, 2024. Período de 2022 a 2024. Acesso em: 23 jan. 2025.
- [5] BANDARA, K., HYNDMAN, R. J., AND BERGMEIR, C. Mstl: A seasonal-trend decomposition algorithm for time series with multiple seasonal patterns. *International Journal of Operational Research* (2022). In press.
- [6] BERGMEIR, C., HYNDMAN, R. J., AND BENÍTEZ, J. M. Bagging exponential smoothing methods using stl decomposition and box-cox transformation. *International Journal of Forecasting* 32, 2 (2016), 303–312.

¹⁰Ver mais em: Brownlee (2018) [9]

- [7] BOLLERSLEV, T. Generalized autoregressive conditional heteroskedasticity. *Journal of Econometrics* 31, 3 (1986), 307–327.
- [8] BOX, G. E., AND JENKINS, G. M. *Time Series Analysis: Forecasting and Control*. Holden-Day, San Francisco, CA, 1970.
- [9] BROWNLEE, J. *Deep Learning for Time Series Forecasting: Predict the Future with MLPs, CNNs and LSTMs in Python*. Machine Learning Mastery, Australia, 2018.
- [10] CHATFIELD, C. *The Analysis of Time Series: An Introduction*, 5th ed. Chapman and Hall/CRC, London, 1996.
- [11] CLEVELAND, R. B., CLEVELAND, W. S., MCRAE, J. E., AND TERPENNING, I. J. Stl: A seasonal-trend decomposition procedure based on loess. *Journal of Official Statistics* 6, 1 (1990), 3–33.
- [12] DE LIMA, M. M. Sistemas de armazenamento em parques eólicos considerando pld horário e situações de constrained off. Dissertação de mestrado, Universidade Tecnológica Federal do Paraná, Curitiba, 2021.
- [13] EPE. Cadernos de estudo do pde 2034. caderno de consolidação de resultados. Tech. rep., Empresa de Pesquisa Energética / Ministério de Minas e Energia, 2024. Acesso em: 23 jan. 2025.
- [14] EPE. Cadernos de estudo do pde 2034. caderno de mmgd - baterias. Tech. rep., Empresa de Pesquisa Energética / Ministério de Minas e Energia, 2024. Acesso em: 23 jan. 2025.
- [15] GOLDEMBERG, J. O estado atual do setor elétrico brasileiro. *Revista USP - Dossiê Energia Elétrica*, 104 (2015).
- [16] GUJARATI, D. N., AND PORTER, D. C. *Basic Econometrics*, 5th ed. McGraw-Hill Education, New York, 2011.
- [17] HAMILTON, J. *Análise de séries temporais*. Princeton University Press, Princeton, 1994.
- [18] HARRISON, P., AND PEARCE, D. Extrapolation of time series and the determination of control limits. *Journal of the Royal Statistical Society: Series C (Applied Statistics)* 21, 1 (1972), 2–10.
- [19] HOLT, C. C. Forecasting trends and seasonals by exponentially weighted averages. *Carnegie Institute of Technology, ONR Memorandum* (1957). Reprinted in: *International Journal of Forecasting*, 2004, 20(1), pp. 5–10.
- [20] HURTADO, M., O’CONNOR, M., FLYNN, D., AND O’MALLEY, M. Analysis of wind energy curtailment in the ireland and northern ireland power systems. *arXiv preprint arXiv:2302.07143* (2023).
- [21] HYNDMAN, R. J. E ATHANASOPOULOS, G. *Forecasting: Principles and Practice*, 3rd ed. OTexts, Melbourne, Australia, 2021. Accessed on <current date>.

- [22] IEA. World energy outlook 2023. Tech. rep., IEA, Paris, 2023. Licence: CC BY 4.0 (report); CC BY NC SA 4.0 (Annex A).
- [23] IEA. Integrating solar and wind: Global experience and emerging challenges. Tech. rep., IEA, Paris, France, 2024. Acesso em: 23 Jan. 2025.
- [24] LI, J., WANG, C., AND WANG, H. Optimal energy storage scheduling for wind curtailment reduction and energy arbitrage: A deep reinforcement learning approach. *arXiv preprint arXiv:2304.02239* (2023).
- [25] LJUNG, G. M., AND BOX, G. E. P. On a measure of a lack of fit in time series models. *Biometrika* 65, 2 (1978), 297–303.
- [26] LÓPEZ PROL, J., AND ZILBERMAN, D. No alarms and no surprises: Dynamics of renewable energy curtailment in california. *Energy Economics* 126 (2023), 106974.
- [27] MEADE, N. *Forecasting with Exponential Smoothing Methods*. Gower Publishing Limited, Aldershot, England, 1984.
- [28] MENEZES, R. F. A. *Programação Diária da Operação e Formação de Preços em Múltiplos Cenários Considerando Sistemas de Armazenamento de Energia por Bateria*. Tese de doutorado, Universidade Federal de Pernambuco, Recife, 2022.
- [29] MERCEDES, S. S. P., RICO, J. A. P., AND POZZO, L. D. Y. Uma revisão histórica do planejamento do setor elétrico brasileiro. *Revista USP*, 104 (fev. 2015), 13–36.
- [30] NIAZ, H., LIU, J. J., AND YOU, F. Can texas mitigate wind and solar curtailments by leveraging bitcoin mining? *Journal of Cleaner Production* 364 (2022), 132700.
- [31] ONS. Portal de dados abertos ons. conjuntos de dados: Capacidade instalada de geração, carga de energia diária, intercâmbio entre subsistemas e restrição de operação por constrained-off de usinas eólicas., 2024. Período de 2022 a 2024. Acesso em: 23 jan. 2025.
- [32] ONS. Capacidade instalada de geração - composição, 2025. Acesso em: 23 Jan. 2025.
- [33] SILVA, V. E. M. D. *Influência do Tratamento de Dados no Desempenho de Modelos de Previsão da Geração Eólica Usando Informações de Restrição de Potência pelo Operador Nacional do Sistema Elétrico*. Trabalho de conclusão de curso, Universidade Federal do Ceará, Fortaleza-CE, 2023. Disponível em: <https://repositorio.ufc.br/handle/riufc/54035>.
- [34] SILVA, W. C. O. D. *Estudo da Restrição de Geração Eolioelétrica por Constrained-Off e Aplicação da Metodologia de Obtenção de Curva de Produtividade Eólica do Operador Nacional do Sistema Elétrico*. Trabalho de conclusão de curso, Universidade Federal do Ceará, Fortaleza, 2022. Disponível em: <https://repositorio.ufc.br/handle/riufc/54034>.
- [35] TAYLOR, S., AND LETHAM, B. Previsão em escala. *The American Statistician* 72, 1 (2018), 37–45.
- [36] WOOLDRIDGE, J. M. *Introductory Econometrics: A Modern Approach*, 5 ed. South-Western, Cengage Learning, Mason, OH, 2013. Michigan State University.

Apêndice - Análise dos Resíduos do Modelo

Foram realizados testes para avaliar a robustez dos resíduos do modelo cujos resultados são apresentados neste apêndice.

Como é possível observar na Tabela 3, para o teste de autocorrelação Ljung-Box não rejeitamos a hipótese nula ($p\text{-valor} < 0.05$) , indicando que os resíduos não apresentam autocorrelação significativa. O mesmo para o teste de heterocedasticidade: não rejeitamos a hipótese nula de que os resíduos não apresentam heterocedasticidade, indicando homocedasticidade. Para a verificação da normalidade, realizamos o teste de Shapiro-Wilk e o teste de Jarque-Bera. Ambos rejeitaram a hipótese nula de que os resíduos seguem uma distribuição normal.

Tabela 3: Testes aplicados aos resíduos

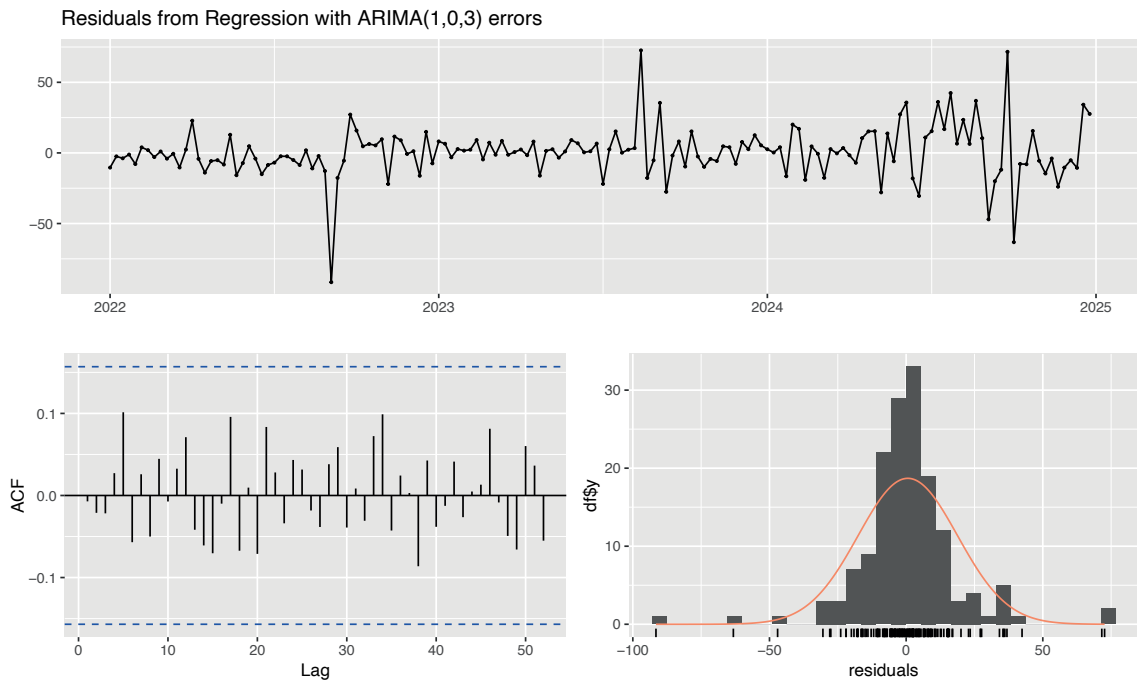
Teste	p-valor
Ljung-Box (Autocorrelação)	0.972
Shapiro-Wilk (Normalidade)	9.421521e-10
Jarque-Bera (Normalidade)	0
ARCH (Heterocedasticidade)	0.892

Apesar dos resíduos não serem distribuídos normalmente, o modelo captura bem a dependência temporal dos dados e não há autocorrelação residual. Um fator relevante nessa análise que nos ajuda a compreender o perfil dos resíduos são as mudanças abruptas características da série temporal do *curtailment* no período analisado, que podem ser os responsáveis por assimetrias nos dados e consequentemente afetaram a normalidade nos resíduos.

Além disso os resíduos apresentaram média 0.61, valor muito próximo de zero, considerando a escala dos dados. Isso associado ao resultado do teste ARCH nos indica que os ruídos tem um comportamento muito próximo ou igual a um passeio aleatório.

Levando esses fatores em consideração, consideramos o modelo robusto à análise dos resíduos e portanto apto para realizar previsões. No gráfico 1 é possível observar a série dos resíduos plotada, bem como a função de autocorrelação parcial (FACP) e o histograma da distribuição dos resíduos.

Figura 1: Resíduos da Regressão com modelo ARIMA (1,0,3)



Fonte: Os autores